

## Střední hodnota náhodné veličiny

... zobecnění průměrného očekávání,  
jde o vážený průměr, kde váhy odpovídají pravděpodobnostem.

- ▶ Kolik šestek průměrně padne při hodu 10 kostkami?
- ▶ Jak dlouho se obvykle čeká na tramvaj?
- ▶ Jaký je průměrný plat? I když většina zaměstnanců má podprůměrný plat, má zas nadprůměrně často narozeniny. 😊
- ▶ Jaká je průměrná škoda při havárii auta, přepočteno na všechna auta daného modelu a rok?
- ▶ Jaká je obvyklý počet uživatelů přihlášených na server?
- ▶ Kolik pevných bodů má náhodně zvolená permutace  $n$  prvků?



Průměrné očekávání závisí na:

... hodnotách, které náhodná veličina nabývá  
... a jejím rozdělení pravděpodobnosti.


# Střední hodnota náhodné veličiny

**Definice:** *Střední hodnota* diskrétní náhodné veličiny  $X$  na prostoru  $(\Omega, P)$  je  $\sum_{\omega \in \Omega} X(\omega)P\{\omega\}$ . Značí se  $E[X]$ .

Na nekonečné  $\Omega$  nemusí součet konvergovat; pak  $E[X]$  neexistuje.

Ukázka:  $X_1$  – hod jednou kostkou

$$E[X_1] = 1 \cdot \frac{1}{6} + 2 \cdot \frac{1}{6} + 3 \cdot \frac{1}{6} + 4 \cdot \frac{1}{6} + 5 \cdot \frac{1}{6} + 6 \cdot \frac{1}{6} = \frac{7}{2}$$



Sloučení jevů se stejnou hodnotou  $x$  náhodné veličiny  $X$  dává vztah  $E[X] = \sum_x xP[X = x]$ , přičemž stačí sčítat přes obor hodnot  $X$ .

## Linearita střední hodnoty

**Věta:** Pro náhodné veličiny  $X$  a  $Y$  na  $\Omega$  s konečnými středními hodnotami a libovolné  $\alpha \in \mathbb{R}$  platí:

- ▶  $E[X + Y] = E[X] + E[Y]$  (linearita vůči součtu) a
- ▶  $E[\alpha X] = \alpha E[X]$  (linearita vůči reálnému násobku).

**Ukázka:**  $X_2$  — hod dvěma kostkami

$X_1'$  — číslo na první kostce,


$X_1''$  — číslo na druhé kostce,

$$X_2 = X_1' + X_1''$$

$X_1'$  a  $X_1''$  mají stejné rozdělení jako  $X_1$ ,

a proto  $E[X_1'] = E[X_1''] = E[X_1]$ .

$$\begin{aligned} E[X_2] &= 2 \cdot \frac{1}{36} + 3 \cdot \frac{2}{36} + \dots + 12 \cdot \frac{1}{36} \\ &= 7 = \frac{7}{2} + \frac{7}{2} = E[X_1'] + E[X_1''] \end{aligned}$$



## Linearita střední hodnoty

**Věta:** Pro náhodné veličiny  $X$  a  $Y$  na  $\Omega$  s konečnými středními hodnotami a libovolné  $\alpha \in \mathbb{R}$  platí:

- ▶  $E[X + Y] = E[X] + E[Y]$  (linearita vůči součtu) a
- ▶  $E[\alpha X] = \alpha E[X]$  (linearita vůči reálnému násobku).

... rozepsáním definic:  $E[\alpha X] = \sum_{\omega \in \Omega} (\alpha X)(\omega) P[\{\omega\}]$

$$= \sum_{\omega \in \Omega} \alpha X(\omega) P[\{\omega\}] = \alpha \sum_{\omega \in \Omega} X(\omega) P[\{\omega\}] = \alpha E[X]$$

$$E[X + Y] = \sum_{\omega \in \Omega} (X + Y)(\omega) P[\{\omega\}] = \sum_{\omega \in \Omega} (X(\omega) + Y(\omega)) P[\{\omega\}]$$

$$= \sum_{\omega \in \Omega} X(\omega) P[\{\omega\}] + \sum_{\omega \in \Omega} Y(\omega) P[\{\omega\}] = E[X] + E[Y]$$

**Poznámka:** Součet i součin lze definovat obecněji i pro náhodné veličiny na *různých* prostorech. Často při opakování pokusu, např. počet orlů při  $n$  hodech mincí je součet  $n$  veličin jednotlivých hodů. Věta o linearitě střední hodnoty platí i v tomto kontextu.

# Indikátor

... pomáhá rozložit složité náhodné veličiny na jednodušší.

**Definice:** *Indikátor* jevu  $A \subseteq \Omega$  je náhodná veličina  $I_A$  taková, že

$$I_A(\omega) = \begin{cases} 1 & \text{pro } \omega \in A, \\ 0 & \text{pro } \omega \notin A. \end{cases}$$

**Pozorování:**  $E[I_A] = \sum_{\omega \in \Omega} I_A(\omega)P[\{\omega\}] = \sum_{\omega \in A} P[\{\omega\}] = P[A]$ .

**Ukázka:** Kolik průměrně padne šestek při hodu  $n$  kostkami?

Označme tuto náhodnou veličinu  $X$ . Pro  $i \in \{1, \dots, n\}$  zavedeme jev  $A_i$  označující, zda na  $i$ -té kostce padla šestka.

Platí  $X = I_{A_1} + \dots + I_{A_n}$  a také  $E[I_{A_i}] = P[A_i] = \frac{1}{6}$ .

Z linearity střední hodnoty dostáváme:

$$\begin{aligned} E[X] &= E[I_{A_1} + \dots + I_{A_n}] \\ &= E[I_{A_1}] + \dots + E[I_{A_n}] \\ &= P[A_1] + \dots + P[A_n] = \frac{n}{6}. \end{aligned}$$



## Ukázky indikátorové metody



Hrajeme-li mariáš, kolik srdcových karet lze očekávat v prvních pěti rozdaných kartách?

Označme tuto náhodnou veličinu  $X$  a pro  $i$  od 1 do 5 zavedeme jevy  $A_i$  obsahující ta rozdání, kde  $i$ -tá karta je srdcová.

Platí:  $X = I_{A_1} + \dots + I_{A_5}$ , ale také  $E[I_{A_i}] = P[A_i] = \frac{8 \cdot 31!}{32!} = \frac{1}{4}$ .

Z linearity dostáváme:  $E[X] = E[I_{A_1}] + \dots + E[I_{A_5}] = \frac{5}{4}$ .

Při výpočtu střední hodnoty nevádí, že jsou jevy závislé.



Zvolíme-li náhodně substituční šifru, kolik písmen zůstane průměrně nezměněno? Neboli, jaká je střední hodnota veličiny  $X$ , znamenající počet pevných bodů náhodné  $n$ -prvkové permutace?

Zavedeme jevy  $A_i$  obsahující permutace, kde  $i$  je pevným bodem. Z  $X = I_{A_1} + \dots + I_{A_n}$  a  $P[A_i] = \frac{(n-1)!}{n!} = \frac{1}{n}$  plyne  $E[X] = n \cdot \frac{1}{n} = 1$ .

## Ukázky indikátorové metody



Rozdělujeme-li náhodně  $n$  úloh na  $n$  serverů, kolik serverů v průměru zůstane nevyužito?

Pravděpodobnostní prostor tvoří možná přiřazení úloh na servery, čili zobrazení z  $n$ -prvkové množiny úloh do  $n$ -prvkové množiny serverů. Odtud  $|\Omega| = n^n$  a pro každé  $\omega \in \Omega$  platí:  $P[\{\omega\}] = \frac{1}{n^n}$ .

Označíme  $X(\omega)$  počet nevyužitých serverů v zobrazení  $\omega$ . (Jde o doplněk oboru hodnot zobrazení  $\omega$  v množině serverů.)

Rozložíme  $X$  na součet indikátorů jevů  $A_i$ , obsahující zobrazení, kde  $i$ -tý server je neobsazený, neboli  $X = I_{A_1} + \dots + I_{A_n}$ .

Každé  $A_i$  obsahuje zobrazení do  $(n-1)$ -prvkové množiny.

Odtud  $|A_i| = (n-1)^n$  a  $P[A_i] = \frac{(n-1)^n}{n^n} = \left(1 - \frac{1}{n}\right)^n$ .

Nyní  $E[X] = E[I_{A_1} + \dots + I_{A_n}] = P[A_1] + \dots + P[A_n] = n\left(1 - \frac{1}{n}\right)^n$ .

Jinými slovy, podíl nevyužitých serverů se limitně blíží  $\frac{1}{e}$ .

# Nezávislé náhodné veličiny

... zjišťování jedné veličiny neovlivní hodnotu jiné

**Definice:** Náhodné veličiny  $X$  a  $Y$  na diskrétním pravděpodobnostním prostoru  $\Omega$  jsou *nezávislé*, pokud pro všechna reálná  $x$  a  $y$  jsou jevy  $\{\omega \in \Omega: X(\omega) = x\}$  a  $\{\omega \in \Omega: Y(\omega) = y\}$  nezávislé.

Formálně:  $\forall x, y \in \mathbb{R}: P[X = x]P[Y = y] = P[X = x \wedge Y = y]$ .

**Ukázky:** Veličiny  $X'_1$  a  $X''_1$  z ukázky o hodu dvěma kostkami (počet ok na první/druhé) jsou nezávislé. Libovolné  $x, y \in \{1, \dots, 6\}$  totiž splňují:  $P[X'_1 = x]P[X''_1 = y] = \frac{1}{6} \cdot \frac{1}{6} = \frac{1}{36} = P[X'_1 = x \wedge X''_1 = y]$ .

Ze skupiny 2 děvčat a 1 chlapce vybereme dvojici. Veličina  $X$  s alternativním rozdělením udává, zdali byl chlapec vybrán v prvním kroku, a  $Y$  v druhém.

Tyto veličiny jsou závislé, neboť pro  $x = 1$  a  $y = 1$  máme:  $P[X = 1]P[Y = 1] = \frac{1}{3} \cdot \frac{1}{3} \neq 0 = P[X = 1 \wedge Y = 1]$ .



Image by Freepik.



# Nezávislé náhodné veličiny

... zjišťování jedné veličiny neovlivní hodnotu jiné

**Definice:** Náhodné veličiny  $X$  a  $Y$  na diskrétním pravděpodobnostním prostoru  $\Omega$  jsou *nezávislé*, pokud pro všechna reálná  $x$  a  $y$  jsou jevy  $\{\omega \in \Omega: X(\omega) = x\}$  a  $\{\omega \in \Omega: Y(\omega) = y\}$  nezávislé.

Formálně:  $\forall x, y \in \mathbb{R}: P[X = x]P[Y = y] = P[X = x \wedge Y = y]$ .

**Věta:**

Pro *nezávislé* náhodné veličiny  $X$  a  $Y$  platí:  $E[XY] = E[X]E[Y]$ .

**Ukázka:** Střední hodnota *součinu* počtů ok padlých na dvou kostkách je podle definice:

$$\frac{30+24+18+12+6+20+15+10+5+12+8+4+6+3+2}{18} + \frac{36+25+16+9+4+1}{36} = \frac{91}{36} + \frac{175}{18} = \frac{441}{36} = \frac{49}{4}$$

36	30	24	18	12	6
25	20	15	10	5	
16	12	8	4		
9	6	3			
4	2				
1					

Protože jde o součin dvou nezávislých veličin  $X'_1$  a  $X''_1$ ,

platí podle věty:  $E[X'_1 X''_1] = E[X'_1]E[X''_1] = \frac{7}{2} \cdot \frac{7}{2} = \frac{49}{4}$

## Nezávislé náhodné veličiny

... zjišťování jedné veličiny neovlivní hodnotu jiné

**Definice:** Náhodné veličiny  $X$  a  $Y$  na diskrétním pravděpodobnostním prostoru  $\Omega$  jsou *nezávislé*, pokud pro všechna reálná  $x$  a  $y$  jsou jevy  $\{\omega \in \Omega: X(\omega) = x\}$  a  $\{\omega \in \Omega: Y(\omega) = y\}$  nezávislé.

Formálně:  $\forall x, y \in \mathbb{R}: P[X = x]P[Y = y] = P[X = x \wedge Y = y]$ .

**Věta:**

Pro *nezávislé* náhodné veličiny  $X$  a  $Y$  platí:  $E[XY] = E[X]E[Y]$ .

... z definic plyne: 
$$E[X]E[Y] = \left(\sum_x xP[X = x]\right)\left(\sum_y yP[Y = y]\right) = \sum_x \sum_y xyP[X = x]P[Y = y] = \sum_x \sum_y xyP[X = x \wedge Y = y]$$


Seskupením  $x$  a  $y$  splňujících  $xy = z$  dostáváme:

$$\sum_x \sum_y xyP[X = x \wedge Y = y] = \sum_z zP[XY = z] = E[XY].$$

# Rozptyl náhodné veličiny

... popisuje, jak se hodnoty náhodné veličiny liší od průměrného očekávání.

**Definice:** *Rozptyl* náhodné veličiny  $X$  je  $E[(X - E[X])^2]$ . Značí se  $\text{Var}[X]$ .




**Pozorování:** Pro rozptyl platí:  $\text{Var}[X] = E[X^2] - (E[X])^2$ .

**Ukázka:**  $X_1$  – hod jednou kostkou

$$\text{Var}[X_1] = \frac{1}{6} \left[ \frac{25}{4} + \frac{9}{4} + \frac{1}{4} + \frac{1}{4} + \frac{9}{4} + \frac{25}{4} \right] = \frac{35}{12}$$


$$\text{Var}[X_1] = E[X_1^2] - (E[X_1])^2 = \frac{1+4+9+16+25+36}{6} - \frac{49}{4} = \frac{182-147}{12} = \frac{35}{12}$$



## Rozptyl náhodné veličiny

... popisuje, jak se hodnoty náhodné veličiny liší od průměrného očekávání.

**Definice:** *Rozptyl* náhodné veličiny  $X$  je  $E[(X - E[X])^2]$ . Značí se  $\text{Var}[X]$ .



**Pozorování:** Pro rozptyl platí:  $\text{Var}[X] = E[X^2] - (E[X])^2$ .

$$\begin{aligned} \dots \text{Var}[X] &= E[(X - E[X])^2] = E[X^2 - 2XE[X] + (E[X])^2] = \\ &= E[X^2] - 2E[X]E[X] + E[(E[X])^2] = E[X^2] - (E[X])^2 \end{aligned}$$

## Odhady pravděpodobnosti výjimečných jevů

Markovova nerovnost: Pro *nezápornou* náhodnou veličinu  $X$  a všechna  $a \in \mathbb{R}$  platí:  $P[X \geq a] \leq \frac{E[X]}{a}$ .

Důsledek:  $P[X \geq tE[X]] \leq \frac{1}{t}$  ... dosazením  $a = tE[X]$ .

Ukázky: Pravděpodobnost, že při hodu 10 kostkami padnou alespoň 3 šestky je nejvýše  $\frac{5}{9}$ :  $P[X \geq 3] \leq \frac{10/6}{3}$ .



Server zpracuje v průměru 1 000 dotazů za jednotku času.

Jak lze omezit pravděpodobnost, že bude překročen limit 1 500 dotazů?  $P[X \geq 1\,500] \leq \frac{1\,000}{1\,500} = \frac{2}{3}$

Čebyševova nerovnost: Pro *každou* náhodnou veličinu  $X$  a všechna  $a \geq 0$  platí:  $P[|X - E[X]| \geq a] \leq \frac{\text{Var}[X]}{a^2}$ .

Pokračování ukázky: Jak se změní odhad pravděpodobnosti zahlcení serveru, pokud *navíc víme*, že  $X$  má rozptyl 200?

$$\begin{aligned} P[X \geq 1\,500] &= P[X - 1\,000 \geq 500] \\ &\leq P[|X - 1\,000| \geq 500] \leq \frac{200}{500^2} = 0,08\% \end{aligned}$$

## Odhady pravděpodobnosti výjimečných jevů

Markovova nerovnost: Pro *nezápornou* náhodnou veličinu  $X$  a všechna  $a \in \mathbb{R}$  platí:  $P[X \geq a] \leq \frac{E[X]}{a}$ .

Důsledek:  $P[X \geq tE[X]] \leq \frac{1}{t}$  ... dosazením  $a = tE[X]$ .

... rozepsáním a odhady:  $E[X] = \sum_x xP[X = x] \geq$

$$\sum_{x \geq a} xP[X = x] \geq \sum_{x \geq a} aP[X = x] = a \sum_{x \geq a} P[X = x] = aP[X \geq a]$$

Čebyševova nerovnost: Pro *každou* náhodnou veličinu  $X$  a všechna  $a \geq 0$  platí:  $P[|X - E[X]| \geq a] \leq \frac{\text{Var}[X]}{a^2}$ .

... do Markovovy nerovnosti ve tvaru  $P[Y \geq b] \leq \frac{E[Y]}{b}$

dosadíme  $Y = (X - E[X])^2$  a  $b = a^2$ , čímž dostaneme:

$$P[(X - E[X])^2 \geq a^2] \leq \frac{E[(X - E[X])^2]}{a^2} \Leftrightarrow P[|X - E[X]| \geq a] \leq \frac{\text{Var}[X]}{a^2}$$

## Kvíz — řešení

Je-li u některých otázek více možností správných, vyberte všechny.

1. Pravda nebo lež? Rozptyl veličin  $X$  a  $X + 5$  je stejný.
2. Střední hodnota binomického rozdělení s parametry  $n$  a  $p$   
a)  $np$ , b)  $p^n$ , c)  $p^n(1 - p)^n$ , d)  $np(1 - p)$ , e)  $p^n + (1 - p)^n$ .
3. Jakou hodnotu bychom dostali, pokud bychom odchylku náhodné veličiny  $X$  od průměru měřili výrazem  $E[X - E[X]]$ ?  
a)  $0$ , b)  $\frac{1}{2}E[X]$ , c)  $E[X]$ , d)  $\sqrt{\text{Var}[X]}$ .
4. Má-li náhodná veličina  $X$  rozptyl  $a$ , potom  $2X$  má rozptyl  
a)  $\sqrt{a}$ , b)  $\sqrt{2a}$ , c)  $a$ , d)  $2a$ , e)  $a^2$ , f)  $4a$ , g)  $4a^2$ .
5. Pravda nebo lež?  
Jsou-li náhodné veličiny závislé, potom  $E[XY] \neq E[X]E[Y]$ .

## Otázky k porozumění tématu přednášky

- ▶ Jak lze spočítat *přesnou* pravděpodobnost, že při hodu 10 kostkami padnou alespoň 3 šestky? Vyjde  $\frac{13\,671\,875}{30\,233\,088} \doteq 45\%$ .
- ▶ Lze k Markovově a Čebyševově nerovnosti nalézt i nějaký netriviální *dolní* odhad na pravděpodobnost?



## Poznámky k pojmosloví a značení

Příbuzný pojem ke střední hodnotě je *medián*.

Zjednodušeně řečeno jde o  $m$  takové, že  $P[X \leq m] = P[X \geq m]$ , čili  $m$  je „uprostřed“ hodnot nabývaných  $X$ .

*Směrodatná odchylka* je odmocnina z rozptylu.

Střední hodnota se někdy značí  $\mu$  (angl. *mean*), směrodatná odchylka  $\sigma$  (*standard deviation*) a rozptyl pak  $\sigma^2$  (*variance*).

Nezávislost náhodných veličin se často definuje pomocí nerovností:

$$\forall x, y \in \mathbb{R}: P[X \leq x]P[Y \leq y] = P[X \leq x \wedge Y \leq y],$$

protože tento vztah má smysl i pro spojité náhodné veličiny.

Pro diskrétní náhodné veličiny je ekvivalentní vztahu s rovnostmi.